

機械学習の前日日射予報への応用

Application of machine learning to one day-ahead solar power forecasting

高松 尚宏^{*1}・中島 虹^{*1}・大竹 秀明^{*1,2}・大関 崇^{*1}

1. はじめに

1.1 地球温暖化問題とカーボンニュートラル

大気中の二酸化炭素の増加がもたらす気温上昇について、スウェーデンの化学者であったアレニウスが1896年に理論的な予測を行っていたことが知られている。アレニウスによる予測から約90年後、1985年に開かれたフィラハ会議において、観測データに基づく気温上昇の予測と人類に及ぼす影響の大きさについて科学者の声明がだされたことで、地球温暖化問題に対し各国が協力して解決を目指すための国際的な協力体制が敷かれるようになった。そして、2015年には国連気候変動枠組条約第21回締約国会議（COP21）でのパリ協定により世界共通の目標として世界の平均気温上昇を（産業革命以前に比較して）1.5℃に抑える努力目標（1.5℃目標）が掲げられるとともに、途上国を含めた世界各国・地域で二酸化炭素などの温室効果ガスの排出削減に向けた努力が求められることとなった。

しかしながら、地球温暖化に関する最新の研究成果を整理・評価し報告書をまとめる組織である「気

候変動に関する政府間パネル（IPCC）」が2018年に公表した1.5℃特別報告書（SR15）¹⁾から、パリ協定当初の温室効果ガス削減目標では1.5℃目標の達成が困難であるとともに、努力目標達成のためには2050年近傍までにカーボンニュートラルを実現する必要があるとされるようになった（SR15を踏まえた内容はIPCC第6次評価報告書[AR6]第1作業部会[WG1]報告書に取りまとめられ、その政策決定者向け要約[SPM]の和訳²⁾が気象庁により公開されている）。SR15の報告を受けて、世界各国で2050年に向けてカーボンニュートラルを目指す取り組みが宣言され、我が国でも2020年10月26日の菅内閣総理大臣所信表明演説³⁾で2050年までのカーボンニュートラル実現を目指すという宣言がなされた。

1.2 太陽光発電と電力システム

2050年までのカーボンニュートラル実現に向けた取り組みを含めて、我が国の第6次エネルギー基本計画⁴⁾が2021年に策定された。その中で、再生可能エネルギーについて「主力電源として最優先の原則の下で最大限の導入」することに取り組むこととしており、2030年の電力システムの電源構成で再生可能エネルギーを36%-38%（太陽光発電は14%-16%）見込むものとしている。2021年度の発電実績⁵⁾と2030年度の電源構成を比較したものが、図1となる。2021年度に対し2030年度には、発電量で太陽光を約1.6倍、風力を約5.0倍に増加させつつ、省エネルギー等により総発電量を約10%削減することを見込むという野心的な目標となっている。

また、2050年に向けての太陽光発電設備の導入については、2021年9月末に約64GWであったも

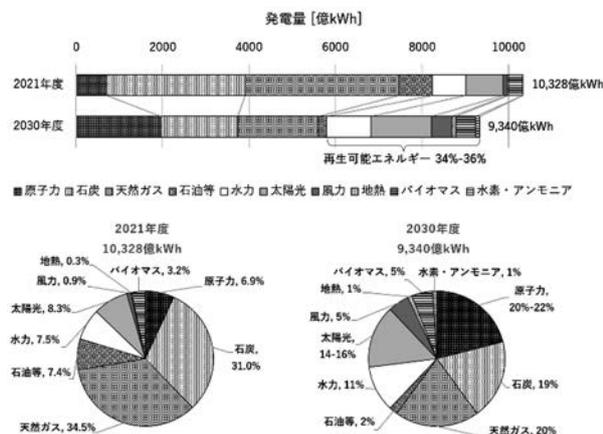


図1 2021年発電実績と2030年の電源構成

*1 産業技術総合研究所

*2 気象研究所

のを、2030年度に100GW-120GWとすることを目標とする⁶⁾とともに、広域連系系統のマスタープランのベースシナリオとして2050年度に260GW(一定条件のもとで試算された参考値)に拡大することも視野に含まれている⁷⁾(図2)。年毎の導入量という点でみると、これは2030年までに約5.2GW/年としつつ、2030年から2050年の間に約7.5GWと更に導入量を加速させていくことに相当する。一方、このような太陽光発電の大量導入を実現するには、電力システムとの連系における制約を緩和する必要がある。

電力システムでは、電力の需要と供給を常に一致させる制約(同時同量制約)があり、安定なシステム運用のためにこの制約を満たす必要がある。しかしながら、電力システムに太陽光発電が大量に導入されると、太陽光発電の出力が気象条件に依存し不安定であることから、同時同量制約を満たして安定にシステムを運用することが難しくなる。そのため、太陽光発電の出力不安定性を補うための対策が必要となる。この問題に対応するひとつの方法として、気象予測を活用した太陽光発電量の予測および予測に基づく電力システムの運用計画の策定が挙げられる。

電力システム運用者(TSO)は、前々日および前日の気象予測に基づき対象日のシステム運用計画を策定する。この運用計画には、太陽光発電等の出力予測の誤差に対応するための調整用火力発電の調達などが含まれており、当日の運用において調整用の電源を活用し、安定した電力供給ができるようにシステム運用を行っている。一方で、安定な電力供給を保障するために、調整電源の調達費用など追加的なコストが発生している。そして、これらのコストは社会的なコストとして電力小売事業者を介して需要家から徴収されることとなる。

計画段階での太陽光発電出力の予測誤差を改善することで、調整電源の調達量を減らすとともに、社会的なコストの発生を抑制することが可能となるこ

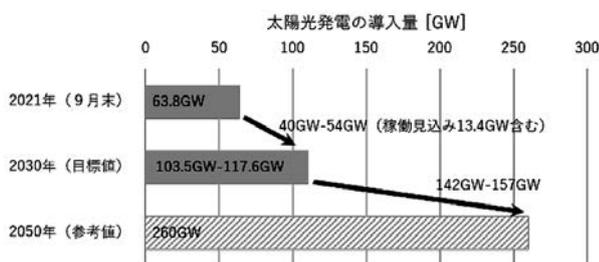


図2 今後の太陽光発電導入量 (参考値を含む)

とから、今後の太陽光発電の導入拡大のためにも、太陽光発電の出力予測を改善することが重要となる。

1.3 卸電力市場と前日日照予報

電力自由化の進展とともに卸電力市場が我が国の販売電力量に占めるシェアも拡大してきた。(これには、旧一般送配電事業者の自主的な取り組みによるところも大きい)

卸電力市場の主な市場として、先物市場、スポット市場(前日市場)、時間前市場(当日市場)の3つの市場が存在する。この中でも、特にスポット市場の電力取引量が支配的であり、2019年6月以降、我が国の販売電力量の35%-45%がスポット市場で取引されている状況にある⁸⁾(図3)。

スポット市場の取引のために、市場参加者は前日10時までに入札を行う仕組みとなっていることから、入札者はそれ以前に当日の太陽光発電出力を予測する必要がある。そのため、スポット市場を対象とする場合、日照予報の中でも前日日照予報が重要となる。

2. 数値気象予報と機械学習

日照予報はベースとするデータ等の違いにより以下の3種類に分類される。

- 地上観測ベース
- 衛星画像ベース
- 数値気象予報ベース

それぞれの予報は得意とする予報リードタイムが異なり、地上観測ベースは1時間以内、衛星画像ベースは1時間先~6時間先程度、そして数値気象予報ベースは6時間先以上の予報リードタイムの領域を得意としている(図4)。そのため、前日予報を想定した時、数値気象予報ベースの予報値を活用することが第一の選択肢となる。

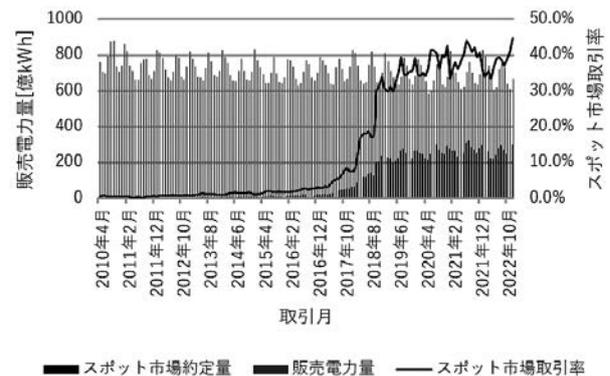


図3 スポット市場の約定量と取引率

気象庁が提供する数値予報モデルには、全球モデル (GSM)、メソモデル (MSM)、局地モデル (LFM) の3種類のモデルがあり、それぞれのモデルは、対象とする気象現象の空間的広さと時間的寿命によって使い分けられる (図5)。前日日射予報の場合、時空間スケールのバランスから MSM が特に用いられることが多い。

予報には必ず予測誤差が含まれることから、より精度の高い予測値を取得するために、数値予報モデルによる生の予測値を統計的に補正することがある。この処理はモデル出力統計 (MOS) と呼ばれる。

数値予報に対する機械学習は後処理として有効であり、数値気象予報モデルが出力する前日日射予報を説明変数として学習モデルを構築することで、予報精度を向上させることができる。

3. 機械学習の基礎知識

3.1 機械学習の種類

機械学習について様々な定義の仕方ががあるが、その多くで共通することは、与えられたデータに対して計算機が自動的に法則性を学習することであると言える。そして、計算機が発見した法則 (学習モデル) は様々なタスクに適用できることから、様々な分野でひろく利用されている。

機械学習は、学習によって得られる法則から実施

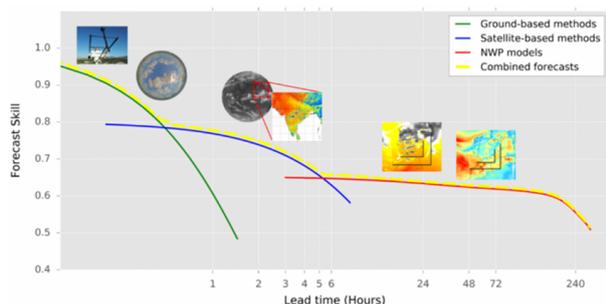


図4 日射予報の精度とリードタイムの関係⁹⁾

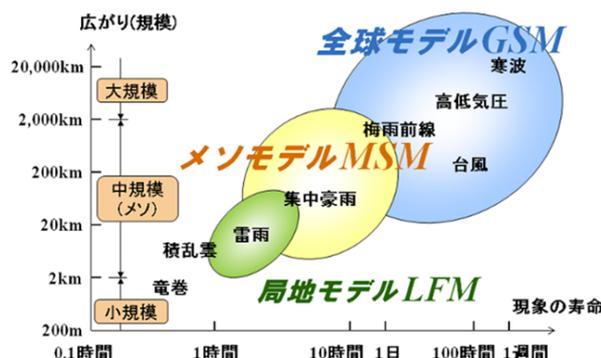


図5 数値予報モデルの空間・時間スケールの対象¹⁰⁾

可能なタスクによって、図6のように分類される。それぞれの学習モデルが行うタスクは、教師あり学習は回帰と分類、教師なし学習はクラスタ解析や特徴抽出 (次元圧縮)、強化学習は最適行動の決定、となっている。

前日日射予報では、主に教師あり学習と教師なし学習を使用することから、以下ではこれらについて解説をする。

3.2 教師あり学習

教師あり学習は、正解となるラベル (目的変数) が与えられた訓練データセットから法則を見つけ、入力される新しいデータ (説明変数) に対して正解を推定する学習となる。

回帰と分類のそれぞれのイメージを図7に示す。回帰タスクは訓練データから回帰式を構成する学習であり、予測は構成した回帰式から日射予報や風速予測を出力することに相当している。一方で分類タスクは、入力データからそのサンプルが所属するカテゴリの確率を予測することに相当しており、これを用いることで気象警報や異常診断などが可能となる。

両者の違いは、取り扱う目的変数が、量的変数か、カテゴリカル変数か、の違いであるともいえるが、問題を再構成することで回帰タスクを分類タスクとして扱うことも可能となる。例えば、量的変数として与えられた目的変数をヒストグラムのビンとしてカテゴリカル変数に変換 (ビンニング) し、分類器か

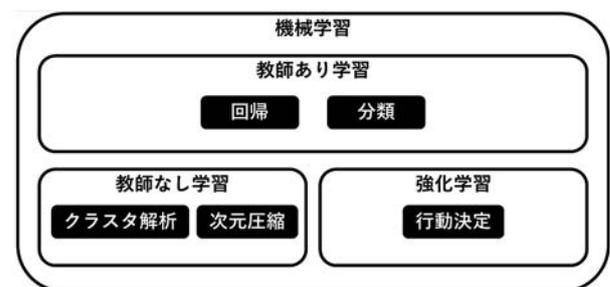


図6 機械学習の種類

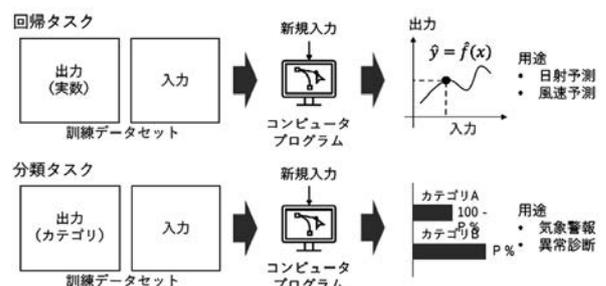


図7 教師あり学習による回帰と分類

ら出力された各カテゴリの推定確率から期待値を推定する、という方法を用いることもできる。

教師あり学習の代表的なアルゴリズムの一例として、以下のものが挙げられる。

- 木構造ベースアルゴリズム
 - 決定木 (DT)
 - ランダムフォレスト (RF)
 - 勾配ブースティング決定木 (GBDT)
- ニューラルネットワーク (NN)
- サポートベクターマシン (SVM)

木構造ベースアルゴリズムは決定木とよばれる分類器をベースとした学習器であり、単一決定木の利用、または複数の決定木を統合するアンサンブルモデルの構成方法によっていくつかの種類に分類される。

決定木は単純な分類器であり、データに対し各ノードで条件分岐を行うことで正解(データの法則)を推定するモデルである。ランダムフォレストはブートストラップ法によって構成した決定木群の出力平均をモデル出力とする構造となっており、このような予測値の統合方法はバギングと呼ばれる。一方で、勾配ブースティング決定木は、決定木の予測誤差を補正するように新たな決定木を追加していくことで精度の良い予測を達成するというアプローチにより構成されており、これはブースティングと呼ばれる。バギングは過学習が発生しにくい一方で、ブースティングはバギング以上に精度向上が期待できるものの過学習を発生させやすいことから、モデル構築時にはパラメータなどの設定に注意が必要である。また、木構造ベースアルゴリズムは、条件分岐によって推定値を出力することから、前処理として変数の標準化が不要であることに加え、変数の重要度を推定しやすい、という利点がある。

ニューラルネットワークは、パーセプトロンと呼ばれるノードを層状に連結させた構造の学習モデルとなっており、層数によって多層パーセプトロン(MLP)や深層ニューラルネットワーク(DNN)とも呼ばれる。学習モデル構成の自由度が高いことに加え、GPUによる効率的な計算が可能であり、勾配消失等への対策手法が普及したことでひろく利用されるようになった。ニューラルネットワークは、後述する教師なし学習でオートエンコーダ等にも利用されており、教師あり学習以外への適用も可能である。

サポートベクターマシンは、カーネル法によって射影された高次元空間上で、各カテゴリデータの境

界面とのマージンを最大化(回帰タスクでは ϵ 許容誤差関数による損失評価を最小化)して学習モデルを構築する手法である。正則化項を用いた最適化により過学習が発生しにくいことが知られている。

アルゴリズムの選択については、モデルの学習サンプルや入力とする特徴量の数によって優位なモデルが変わるため、一般的にどのモデルを使用すべきかを論ずることは難しい。参考情報ではあるが、2022年にMarkovicsらが行った機械学習モデルの日射予報精度の比較¹¹⁾によれば、サポートベクターマシンが安定して高い性能をだした結果となっている。一方で、サポートベクターマシンは不要な特徴量が増えると性能が悪化しやすいことから、データセットによってはランダムフォレストなど不要な特徴の悪影響を受けにくい手法がより適していることもある。そのため、複数のモデルについて精度を比較し、そのうえで採用するアルゴリズムを選択することが実用的にはおこなわれる。

3.3 教師なし学習

教師あり学習がデータ(説明変数)について正解(目的変数)との関係性を学習するのに対し、教師なし学習はデータ自身が持つ構造についての法則を見つけ出す学習となる。そのため、教師なし学習では正解データが不要となる。

教師なし学習のイメージを図8に示す。多数の説明変数を有するテーブルデータが与えられたときに、説明変数を縮約して2次元空間などへの低次元空間でデータの特徴を効率よく表現してデータを圧縮するとともに、テーブルデータ内の各サンプルについて関係性を可視化・クラスタリングすることができる。

教師なし学習の代表的なアルゴリズムの一例として、下記を挙げることができる。

- 主成分分析 (PCA)
- 自己組織化マップ (SOM)
- オートエンコーダ (AE)

主成分分析は古典的ながらも非常に有用な統計分析として知られる。データの分散を情報量として分

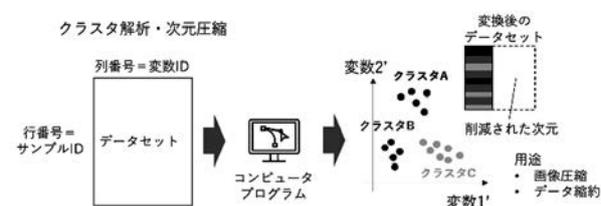


図8 教師なし学習によるクラスタ解析・次元圧縮

散を最大限説明できる基準軸となるように座標変換を行うことで、相関のある説明変数を統合してより少数の変数でデータを説明できるようにする手法である。線形変換がベースである一方、抽出される主成分についてデータ全体の情報（分散）を説明する寄与率および説明変数との関係性を明示的に把握でき、結果の解釈性に優れる。

自己組織化マップは、逐次学習またはバッチ学習により、データ空間（各説明変数を軸とした高次元空間）上で与えられるサンプル集合について、サンプルごとの局所的な近傍関係をそれぞれ学習してひとつのマップとして接続することで、すべてのサンプルの位置関係を二次元マップなどの低次元写像として経験的に獲得する手法となる。サンプル集合がデータ空間より低次元の多様体のうえで存在しているという仮定から低次の表現を得る学習である多様体学習のひとつに相当している。

オートエンコーダは、ニューラルネットワークの一種であり、入出力層と隠れ層を持つ3層以上の構成で入力データそのものを出力層で比較・学習するデータとしている。オートエンコーダの隠れ層は出力データを表現する潜在変数とみなすことができ、ネットワークを学習させることにより、データの潜在変数を推定していることとなる。また、学習したオートエンコーダに対して隠れ層を入力層として扱うことで、生成モデルとして利用することが可能であり、画像生成などにも応用されている。

主成分分析とオートエンコーダは画像情報を圧縮して表現し、教師あり学習を効率的におこなうために用いることができる。また、自己組織化マップなどの多様体学習は、サンプルの特徴を二次元マップなどの表現に変換してサンプル同士の関係性を可視化するのに用いられることが多い。

4. 機械学習モデルの前日日射予報への適用方法

4.1 日射予測モデルの設計

前述した教師あり学習と教師なし学習を複数組み合わせ、モデルを構成することが可能である。図9にモデルの構成例を示す。この例では、気象予報データを説明変数、日射の地上観測データを目的変数とした日射予報モデルを想定した。基本的には、数値気象予報の格子点（GPV）データや気象画像のピクセルデータ、地上観測データをひとつのテーブルデータとして表し、最終的に教師あり学習として回帰タスクに用いる。このとき、気象画像に対して

教師なし学習を用いることで次元削減を行い、説明変数について効率的に低次元化された表現を得ることで、計算負荷の低減を図ることも可能である。また、教師あり学習の前に、テーブルデータへ教師なし学習を適用して特徴抽出を行うことも可能である。上述したモデル構成は一例であり、設計者のアイデアにより様々な構成を与えることができる。

設計する日射予報モデルを実装するために、ソフトウェアや各種パッケージを利用することが可能である。商用ソフトウェアとして、大学などの研究機関ではMATLABとその機械学習用ツールボックスが使用されることが多い。一方、オープンソースのソフトウェアとしてRやpythonを無償で利用することも可能であり、豊富な統計分析および機械学習関連パッケージを追加して利用できる。

4.2 データの取得

前日日射予測の場合、数値予報データを説明変数とすることが多い。日本では、気象庁の数値予報データとしてMSMデータ等が気象業務支援センターを通して配信されているが、教育研究目的であれば、京都大学生存圏研究所の生存圏データベースから無償で利用することができる。気象庁の気象予報データはGRIB2形式で提供されており、データの抽出やcsvファイルへの変換には、バイナリを直接読み込むか、米国海洋大気庁（NOAA）が提供するwgrib2と呼ばれるGRIB2処理用のプログラムを用いる。

目的変数とするデータとして、地上観測された全天日射を採用することも可能である。この場合、気象庁のホームページから過去の観測データが公開されており、csvファイルとしてダウンロードできる。全天日射は全国57地点の気象官署で観測されており、前1時間平均データとして公開されている。また、電力エリアの太陽光発電量を目的変数とする場合には、送配電事業者のホームページで過去のエリア需給実績がcsvファイルで公開されており、太陽

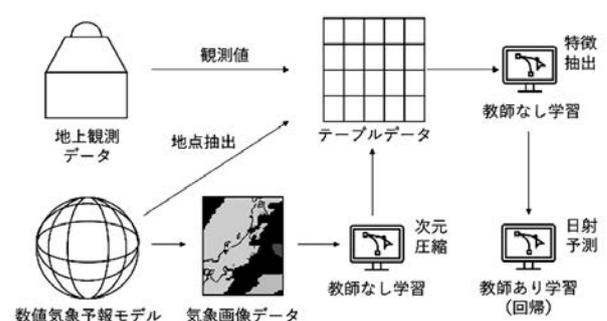


図9 日射予測モデルの構成例

光発電の実績データを使用することも可能である。

4.3 モデルの検証と評価

データセットについて、訓練データとテストデータの2種類に分割して取り扱う必要がある。訓練データはモデルの学習やパラメータ調整に用いられ、テストデータは訓練データから学習したモデルの評価に用いられる。

訓練データと評価データの分割には、以下の3種類の方法がある(図10)。

- ホールドアウト
- クロスバリデーション
- ウォークフォワード

ホールドアウトは、訓練データとテストデータを完全に分離する方法となる。単純な分割であり、少ない計算負荷で評価を行うことができる一方、データ数が少ないと十分な評価ができないといった欠点がある。

クロスバリデーションは、データセットをN個の集合へ分割し、テストデータを順次切り替えてN回のテストを行う評価方法となる。ホールドアウトと比較してデータを有効に活用しているため、比較的少数のデータで評価を行う際にも適している。一方、時系列データなどのサンプル間の順序が重要な意味を持つデータへの適用には、順序関係を無視した評価を行ってしまうために課題が残る。

ウォークフォワードは時系列データを想定した方法であり、テストデータと訓練データのタイムウィンドウを時系列に沿って変化させ、順々に評価を行っていく方法である。そのため、この方法はサンプル間の順序関係を維持してモデルの学習と評価を行うのに適している。また、テストデータに対する訓練データの与え方には、大きく2通りあり、訓練データに一定の区間を定めてテストデータとともに移動させる方式と、テストデータ以前のデータをすべてモデルの訓練に使用する方式がある。

上述した3種類の方法について、データの特性、評価目的、計算負荷の観点から、評価者が適切な分

割方法の選択を行うこととなる。日射予測モデルの評価という観点では、時系列関係を維持するためにホールドアウト、ウォークフォワードが厳密な評価において望ましいが、計算負荷やテストデータのサイズの問題からクロスバリデーションが採用される場合もある。

データをテスト用と訓練用に分割後、予測値をテストデータの目的変数と比較し、モデル性能を評価する必要がある。モデルの評価は、指標を用いた定量化とグラフによる可視化のふたつによって行われる。

学習モデルの性能評価のために使用される代表的な指標として、平均バイアス誤差(MBE)、平均絶対誤差(MAE)、平方根平均二乗誤差(RMSE)が存在する。

$$MBE = \frac{1}{n} \sum_{i=1}^n e_i \tag{1}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \tag{2}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \tag{3}$$

ここで、 $e_i (i = 1, 2, \dots, n)$ は予測誤差を表している。MBEは学習モデルの予測誤差の過大・過少傾向を示す指標となる。MAEとRMSEは平均的な予測精度を表しており、RMSEはMAEと比較して相対的に外れ値に敏感な指標となっている。

5. 前日日射予測への機械学習の応用事例

5.1 前日日射予測における大外しの問題

1章にて電力システムと日射予測の関係について述べた。前日日射予測の精度が向上することにより、電力需給当日の計画からのズレが抑えられるため、TSOは調整力(調整用電源等)を用いて電力システムを安定に運用しやすくなる。一方で、当日に調整力を運用するためには、TSOがその容量を決めて事前に調達を行っておく必要がある。

必要調整力の調達は、前日以前の段階で、公募や需給調整市場を通じてTSOにより行われ、調達する容量(Δ kW 価値)に応じたコストが発生する。このコストは、電力システムを安定に運用するために、託送料の一部として最終的に需要家が負担することとなる。そのため、調整力の調達容量を電力システムの安定性に支障がでない範囲で最小限に抑えることが、効率的な電力システムの運営のために重

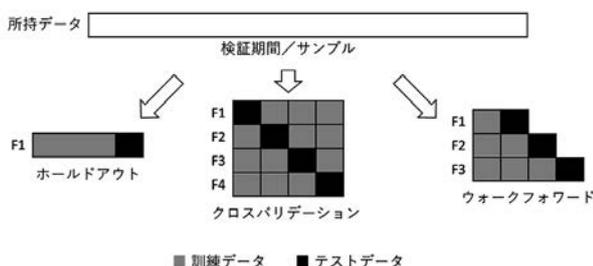


図10 モデル評価のためのデータ分割方法

要となる。

調整力は応動時間と用途により様々な区分がなされるが、そのうちの三次調整力②は需給運用の前日に需給調整市場で取引される。この必要調達量は、残余需要（需要電力－再エネ発電量）の前日予測誤差実績の 3σ 相当値（99.87パーセントイル）を基に決定される¹²⁾ことから、TSOの調整力調達量を抑制するためには、前日予測の平均的な精度（MAEやRMSEなど）のみならず、 3σ 相当の誤差としての「大外し」を抑制する必要がある。

この課題に対し、著者たちは機械学習を使ったアプローチにより過去に研究を行ってきた。機械学習の前日日射予報への応用事例として、以下に紹介をする。

5.2 大外しを抑制する機械学習モデル

一般的な機械学習モデルにおいて、平均的な精度であるRMSEやMAEが最適化指標として回帰モデル構成のために参照される。大外しのような極端な誤差の抑制に注目した学習モデルの構成については、ほとんど研究事例が存在していない。

一方、過学習抑制のための正則化や損失関数へのピンボールロスなどの非対称な関数の適用といった手法を利用することで、大外しを抑制した機械学習モデルを構築することができる。

このような機械学習モデルについて、我々が過去に得た研究結果¹³⁾を図11に紹介する。この機械学習モデルは、気象官署（関東5地点）観測日射の地点平均値を予測するモデルであり、気象庁の数値気象予報データであるMSMデータとメソアンサンプル予報システム（MEPS）データを入力として用いたモデルとなっている。このモデルにおいて、サポートベクターマシンの正則化とピンボールロス損失関数を組み合わせることで大外し抑制効果の高いモデルを構成することができ、従来のMSMによる日射



図11 機械学習モデルによる日射予測の大外し抑制と平均精度の最適化。13)の結果を表した図を改変。

予報に対し、平均精度（RMSE）を維持して大外しを47%程度低減することを可能とした。

この研究では、基本的な機械学習アルゴリズムとしてR言語でliquidSVMパッケージを用いているが、既存パッケージの学習モデル設定を適切に変更することで、目的に特化したモデルを構成することが可能となる。

5.3 機械学習の予測大外し事例分析

数値気象予報の後処理として機械学習モデルを用いることで、系統的な誤差が補正され、全体的には予測精度を改善することができる。一方で、特定のサンプルに注目すると予測精度が悪化していることがある。しかしながら、機械学習で構成される回帰モデルはブラックボックスとなっており、一般的にはそれがなぜ発生したかを説明するには困難が伴う。

このような分析の検討事例のひとつとして、我々が教師なし学習を応用した研究結果¹⁴⁾を紹介する。この研究は、MSM予報データを入力としたランダムフォレストモデルがMSMの元データより大外しを悪化させたサンプル（テストデータ）について解析するために、教師なし学習（そのうちの多様体学習）によって訓練データとテストデータの位置関係を二次元座標に射影するという分析の検討を含んでおり、太陽光エネルギー学会にて口頭発表されたものである。

図12は、大外しが悪化したテストデータと訓練データのサンプル間の位置関係を教師なし学習で可視化した二次元マップ、及びテストデータとその近傍サンプルの時系列データを示している。大外しが悪化したケース（2019-08-30を対象とした予測）に対し、過去60日分で与えた訓練データのうち2019-08-29のサンプルが近傍となるのが二次元マップから判明した結果となっている。

一般的に、教師あり学習では、高次元の特徴空間

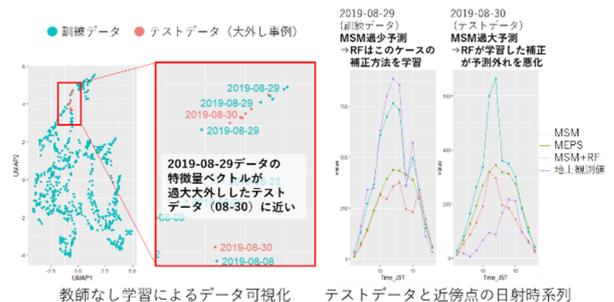


図12 教師なし学習による大外しケースの訓練データとテストデータの可視化とテストデータ近傍サンプルの時系列データ。14)の講演発表の図を改変。

上の訓練データに近傍する点について、訓練データの目的変数に類似した出力（もしくは周辺サンプルから確率的に期待される出力）を発生させるように回帰モデルが構成される。そのため、仮に理想的にサンプル間の位置関係が図 12 の二次元マップ上で表現されていれば、マップ上でテストデータの近傍に配置された訓練データが学習モデルの出力の根拠となったデータに相当していることになる。

この研究で解析した大外し悪化ケース（2019-08-30）とその近傍となる訓練データ（2019-08-29）の時系列を確認すると、2019-08-29 の訓練データでは MSM データが地上観測日射に対し過少予測（観測日射 > MSM データ）となっているのに対し、2019-08-30 のテストデータでは 14 時 -15 時を除き過大予測（観測日射 < MSM データ）となっている。つまり、近傍であるにも関わらず MSM データが過大か過少かで逆傾向の予測を行っていたこととなる。そのため、テストデータにおいて機械学習モデルは MSM の予測誤差を悪化させる方向で補正をしてしまい、学習モデルが大外しを悪化させたということが推察される。

教師なし学習により次元削減だけでなく、二次元マップへの射影などでサンプル間の関係を考察するための材料が得られることから、これを用いることでモデルのデバッグやデータの量が十分であるかなどの検討を行うことも可能となる。

6. おわりに

本稿では、電力システムにおける日射予測の必要性とともに、機械学習技術の基礎知識と前日日射予測への適用方法について解説を行った。また、具体的な応用事例として、我々の過去の研究を紹介し、その結果について概観した。

1 章で紹介したように、カーボンニュートラルに向けて、我が国は太陽光発電システムの導入をますます加速させていくことを目指している。今後の太陽光発電システムの発展のためには、予測分野では以下の研究領域での発展が期待される。

- アンサンブル予測といった確率的な情報を利用した予測精度の向上
- 不確実性や大外しリスクを正確に見積もることを可能とする確率予測
- 予測のユーザビリティ向上による電力市場への新たな価値の提供

電力システムのための予測技術として、単純な精度向上のみならず、その応用が非常に重要となる。

機械学習技術は数値予報データの精度向上に寄与するだけでなく、学習モデルの調整を通じて特定の課題に最適化された予報の提供を可能とする。一方で、課題にあわせたモデルを構成するためには、機械学習アルゴリズムを単純に使用するだけでなく、その背後の原理について概要を知って適用する必要がある。

機械学習を用いた前日日射予測について、本稿が読者の理解の一助となれば幸いである。

謝辞

本稿の 5 章で紹介した研究成果は、NEDO 委託事業「翌日および翌々日程度先の日射量予測技術の開発」(JPNP20015) の一環で進められたものであり、当該研究において気象庁および気象研究所からメソアンサンブル予報データの提供を受けている。

参考文献

- 1) IPCC, 2018 : Global warming of 1.5° C. An IPCC Special Report on the impacts of global warming of 1.5° C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty [V. Masson-Delmotte, P. Zhai, H. O. Pörtner, D. Roberts, J. Skea, P.R. Shukla, A. Pirani, W. Moufouma-Okia, C. Péan, R. Pidcock, S. Connors, J. B. R. Matthews, Y. Chen, X. Zhou, M. I. Gomis, E. Lonnoy, T. Maycock, M. Tignor, T. Waterfield (eds.)] . In Press.
- 2) IPCC 第 6 次評価報告書第 1 作業部会報告書 政策決定者向け要約 暫定訳（文部科学省及び気象庁）(accessed Jun. 22 2023), <https://www.data.jma.go.jp/cpdinfo/ipcc/ar6/index.html>
- 3) 首相官邸、第二百三回国会における菅内閣総理大臣所信表明演説 (accessed Jun. 22 2023), https://www.kantei.go.jp/jp/99_suga/statement/2020/1026shoshinhyomei.html
- 4) 資源エネルギー庁、エネルギー基本計画について (accessed Jun. 22 2023), https://www.enecho.meti.go.jp/category/others/basic_plan/
- 5) 資源エネルギー庁、電力調査統計表 過去のデータ (accessed Jun. 8 2023), <https://www.enecho>

- meti.go.jp/statistics/electric_power/ep002/results_archive.html
- 6) 資源エネルギー庁, 総合エネルギー調査会 省エネルギー・新エネルギー分科会/電力・ガス事業分科会 再生可能エネルギー大量導入・次世代電力ネットワーク小委員会 (第 52 回), 今後の再生可能エネルギー政策について (accessed Jun. 22 2023), https://www.meti.go.jp/shingikai/enecho/denryoku_gas/saisei_kano/052.html
 - 7) 電力広域的運営推進機関, 広域系統長期方針 (広域連系系統のマスタープラン) の策定について (accessed Jun. 22 2023), https://www.occto.or.jp/kouikikeitou/chokihoushin/230329_choukihoushin_sakutei.html
 - 8) 自然エネルギー財団, 統計 | 電力市場 (accessed Jun. 12 2023), <https://www.renewable-ei.org/statistics/electricitymarket/>
 - 9) Diallo, Mouhamet. Solar irradiance forecast and assesment in the intertropical zone. Diss. Université de Guyane, 2018.
 - 10) 気象庁, 令和 4 年度数値予報解説資料集 (accessed Jun. 22 2023), <https://www.jma.go.jp/jma/kishou/books/nwpkaisetu/nwpkaisetu.html>
 - 11) Markovics, David, and Martin Janos Mayer. "Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction." *Renewable and Sustainable Energy Reviews* 161 (2022) : 112364.
 - 12) 電力広域的運営推進機関, 第 35 回需給調整市場検討小委員会, 三次調整力②に関する 2022 年度事後検証および 2023 年度事前評価について (accessed Jun. 22 2023), https://www.occto.or.jp/iinkai/chouseiryoku/jukyuchousei/2022/2022_jukyuchousei_35_haifu.html
 - 13) Takamatsu, Takahiro, Hideaki Ohtake, and Takashi Oozeki. "Support Vector Quantile Regression for the Post-Processing of Meso-Scale Ensemble Prediction System Data in the Kanto Region : Solar Power Forecast Reducing Overestimation." *Energies* 15.4 (2022) : 1330.
 - 14) 高松尚宏, 大関崇, 大竹秀明, 中島虹, 山口浩

司, メソアンサンブル予報システム (MEPS) データを入力とした機械学習モデルの日射予測大外しの分析の基礎検討, 日本太陽エネルギー学会講演論文集 (2022 年 11 月), ROMBUNNO. 86, 福井県 福井市 福井県国際交流会館.

著者略歴



高松 尚宏 (タカマツ タカヒロ) 慶応義塾大学理工学部システムデザイン工学科卒業. 同大学院理工学研究科博士課程修了. 博士 (工学). 現在, 産業技術総合研究所にて, 日射予測技術の研究開発に従事.



中島 虹 (ナカジマ コウ) 2018 年 9 月首都大学東京大学院都市環境科学研究科地理環境科学域博士後期課程修了, 学位取得 (博士 (理学)). 2017 年 7 月 - 2019 年 9 月公益財団法人東京都環境公社東京都環境科学研究所研究員. 2018 年 10 月 - 2019 年 9 月首都大学東京都市環境学部地理環境学科研究員. 2019 年 10 月国立研究開発法人産業技術総合研究所産総研特別研究員. 現在に至る.



大竹 秀明 (オオタケ ヒデアキ) 弘前大学理学部地球科学科卒業. 北海道大学大学院地球環境科学研究科博士後期課程修了. 博士 (地球環境科学). 気象庁気象研究所入所. その後, 国立研究開発法人 産業技術総合研究所入所. 現在, 福島再生可能エネルギー研究所主任研究員. 太陽光発電出力予測の研究開発に従事.



大関 崇 (オオゼキ タカシ) 東京農工大学電気電子工学専攻博士後期課程修了. 博士 (工学). 2005 年国立研究開発法人 産業技術総合研究所入所. 現在, 福島再生可能エネルギー研究所再生可能エネルギー研究センター太陽光システムチーム 研究チーム長. 太陽光発電システムの研究開発に従事.